

Marta Woźniak

Gospodarcze zastosowania algorytmów genetycznych

1. Wstęp

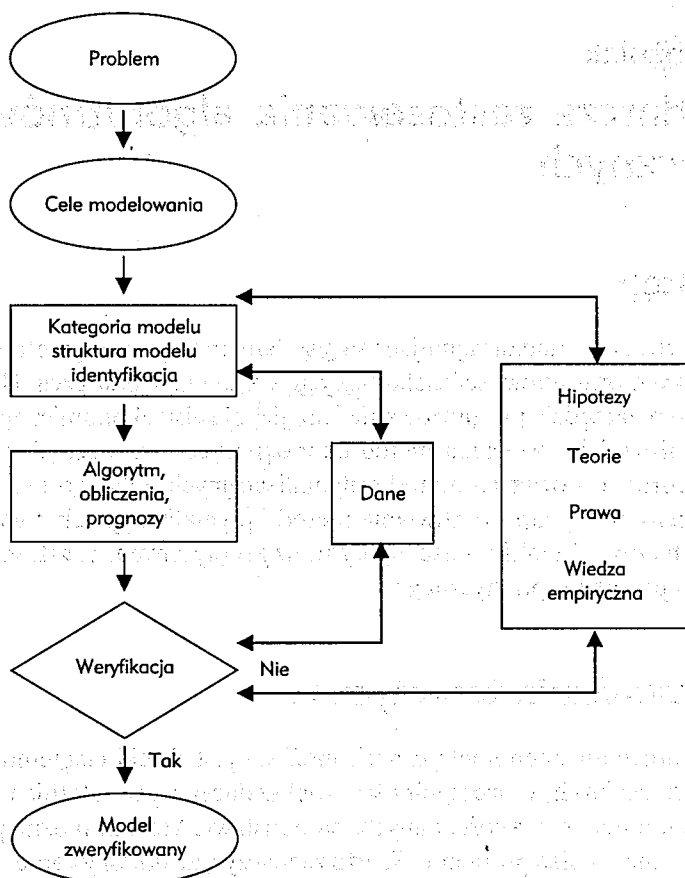
Ekonometria jako nauka zajmująca się ustalaniem za pomocą metod statystycznych ilościowych prawidłowości zachodzących w życiu gospodarczym [1] może być stosowana jako narzędzie prognozowania i analizy zjawisk ekonomicznych. Do rozszerzenia możliwości stosowania metod ekonometrycznych niezbędne wydaje się stosowanie coraz to nowszych metod optymalizacyjnych. Dlatego też w pracy niniejszej podjęto próbę zaprezentowania metod optymalizacyjnych, tworzenia modeli matematycznych, a także opisu algorytmów genetycznych, z zastosowaniem do konkretnego problemu praktycznego.

2. Rozważania teoretyczne

Rozwój procedur ekonometrycznych możliwy jest dzięki ciągłemu rozwojowi technik informacyjnych, w szczególności zwiększającej się w ostatnich latach prawie nieograniczonej dostępności danych, na podstawie których można przeprowadzić odpowiednią analizę problemu. Warto zaznaczyć, że dokonywanie analiz i prognoz nie mogłoby przebiegać sprawnie bez posługiwania się coraz to nowszymi technikami komputerowymi oraz doskonalszym sprzętem, mogącym wykonywać skomplikowane obliczenia. Sprawia to, że możliwe jest przeprowadzenie dokładnych analiz, pozwalających ekonomistom na przewidywanie zjawisk gospodarczych i tym samym na przeprowadzanie odpowiednich w danej sytuacji operacji.

Przez ekonometrię rozumie się niekiedy teorię podejmowania decyzji. Bada ona zależności i prawidłowości zachodzących procesów w otoczeniu, z którym niezerwalnie związana jest optymalizacja, czynności diagnozujące oraz analiza procesu produkcyjnego. W praktyce do rozstrzygania problemów optymalizacyjnych należy zbudować model matematyczny, za pomocą którego opisywana jest rzeczywistość. Tworzenie modelu matematycznego (schematycznie przedstawione na ry-

sunku 1) i dalsze rozstrzygnięcie problemu za pomocą metod matematycznych znajduje szczególne uzasadnienie w przypadku, gdy spotykamy się z koniecznością podejmowania więcej niż jednej decyzji, mając na względzie uzyskanie ściśle określonego celu.

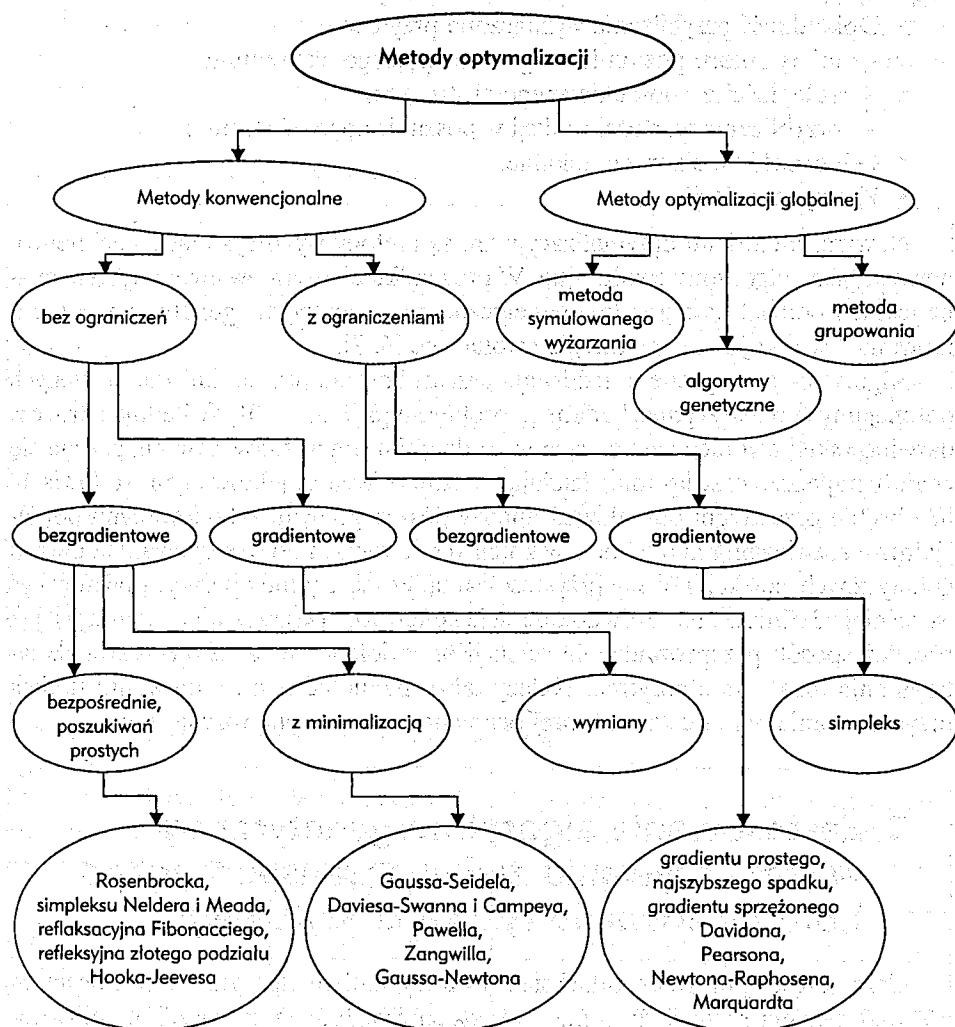


Rysunek 1. Schemat tworzenia modelu

Źródło: opracowanie własne na podstawie [12], s. 2.

Dobór odpowiedniego modelu może również sprawiać pewne kłopoty. Mamy bowiem do wyboru modele liniowe i nieliniowe, deterministyczne (wszystkie zmienne są rzeczywiste) oraz stochastyczne (w których co najmniej jedna zmienna jest losowa). Istnieją także modele, które jedynie opisują rzeczywistość, czyli modele opisowe, bądź modele, w których opis rzeczywistości jest powiązany z dokonaniem wyboru, czyli modele optymalizacyjne. W praktyce większość problemów przedstawiona może zostać za pomocą modeli liniowych, których bezsporną zaletą jest ich

niski stopień skomplikowania. Kolejną ich zaletą jest istnienie kilku dobrze znanych metod rozwiązywania tego rodzaju zadań. Należy dodać, że zbiór takich metod, czyli metod programowania liniowego stanowi część metod optymalizacji [2, 3, 4].



Rysunek 2. Podział metod optymalizacyjnych

Źródło: opracowanie własne na podstawie [5], s. 12-13.

Niezbędne wydaje się podkreślenie, że nie istnieje uniwersalny sposób, który mógłby być zastosowany do rozstrzygania wielu zagadnień. Poszczególne metody powinny być dostosowywane do konkretnej sytuacji, ponieważ tylko właściwie do-

brana metoda pozwala na otrzymanie wyniku minimalnym kosztem. Różnorodność metod widoczna jest na rysunku 2, przedstawiającym podział metod optymalizacyjnych. Do dobrania najlepszej metody optymalizacyjnej najczęściej stosuje się precyzyjnie i dokładnie dobrane kryteria [4, 5]:

- Dokładność przybliżania wyznaczona przy ocenie:
 - miary zbioru poziomowego, otaczającego ekstremum,
 - odległości od poszukiwanego ekstremum,
 - przybliżenia wartości funkcji w poszukiwanym ekstremum.
- Odporność na ekstrema lokalne.
- Koszty symulacji.

Nowymi metodami optymalizacyjnymi są metody wykorzystujące sieci neuronowe, a także algorytmy ewolucyjne. W przypadku algorytmów ewolucyjnych, znany jest ich podział na algorytmy genetyczne, programowanie genetyczne, programowanie ewolucyjne oraz strategie ewolucyjne [6, 7].

Algorytmy genetyczne umożliwiają przeszukiwania przestrzeni zakodowanych potencjalnych rozstrzygnięć badanego problemu [6, 7, 8, 9, 10]. Naśladując procesy darwinowskiej ewolucji zachodzące w środowisku organizmów żywych, starają się znaleźć najlepsze rozwiązanie, działając w sztucznie zaprojektowanym środowisku. W obrębie przestrzeni poszukiwań między poszczególnymi zakodowanymi potencjalnymi rozwiązaniami dochodzi w kolejnych iteracjach do występowania operacji genetycznych, selekcji i oceny przystosowania. Poszczególne operacje powinny być wcześniej zdefiniowane, zarówno operacje genetyczne (krzyżowanie i mutacja), jak również sposób przeprowadzania selekcji oraz dokładnie określony warunek zatrzymania działania algorytmu. Należy także pamiętać o sformułowaniu funkcji przystosowania, na podstawie której oceniane są znalezione rozwiązania.

3. Zastosowanie algorytmu genetycznego w rozwiązywaniu zadania transportowego i prognozowaniu ryzyka kredytowego

Coraz częściej można spotkać się z wykorzystaniem algorytmów ewolucyjnych do rozstrzygania różnych zagadnień praktycznych. Jednym z najczęściej opisywanych jest problem komiwojażera, polegający na zaprojektowaniu trasy przejazdu przez wyznaczone punkty w taki sposób, aby każdy punkt został odwiedzony tylko raz. Trasa powinna zaczynać się i kończyć w tym samym punkcie. W zadaniu tym należy zminimalizować koszty przejazdu.

Nieco inna sytuacja występuje w przypadku zadania transportowego. Poszukiwany jest tu plan najtańszego przewozu towaru (jednego rodzaju) z określonej liczby miejsc nadawczych do określonej liczby miejsc odbioru. Konieczne jest podanie

zapasowej ilości towaru w każdym miejscu nadania, jak i określenie zapotrzebowania w miejscach odbioru. Niezbędne jest dokładne podanie kosztów związanych z przewozem towarów pomiędzy każdym z miejsc nadania i odbioru.

Na podstawie badań i wyników zawartych w [5] przedstawiona została sytuacja, w której jedna firma dostarcza towar jednego rodzaju z magazynów do punktów odbiorczych. Zostało to pokazane w tabeli 1. Koszty transportu na poszczególnych trasach zostały przedstawione w jednostkach kosztu, natomiast popyt i podaż w jednostkach towaru.

Tabela 1. Zestawienie kosztów przewozu

Punkt nadania \ Punkt odbioru	Punkt odbioru 1	Punkt odbioru 2	Punkt odbioru 3	Punkt odbioru 4	Podaż
Magazyn 1	60	82	91	76	500
Magazyn 2	64	83	95	77	450
Magazyn 3	70	85	100	81	560
Magazyn 4	72	90	105	80	280
Popyt	620	420	365	385	

Źródło: opracowanie własne na podstawie [5], s. 125–126.

Tabela 2. Wyniki analizy zagadnienia transportowego

Metoda \ Kryterium	Wartość funkcji kosztów	Poprawa wartości w [%]	Potrzebna liczba iteracji
Badana firma	141 950	—	—
AGR	140 130	1,28	30
AGL	134 810	5,03	27
AGT	139 206	1,93	25

Źródło: opracowanie własne na podstawie [5], s. 127.

W tabeli 2 porównano metodę dotychczas wykorzystywaną przez firmę „X” („ręcznie” ułożony plan transportu) z metodami wykorzystującymi: AGR, czyli algorytm genetyczny z ruletkową metodą selekcji, AGL, czyli algorytm genetyczny z selekcją rankingu liniowego oraz AGT, czyli algorytm genetyczny z selekcją tur-

niejową. Biorąc pod uwagę wyniki przedstawione w tabelach 1 i 2, można zauważyć, że zastosowanie algorytmów genetycznych umożliwia obniżenie kosztów w przedstawionym zadaniu transportowym.

Innym przykładem praktycznego zastosowania algorytmu genetycznego jest prognozowanie ryzyka kredytowego. Najczęściej do tego typu zagadnień stosuje się metody statystyczne. Możliwe jest jednak zastosowanie systemu wykorzystującego programowanie genetyczne do rozwiązywania tego typu problemów. Przykładem tego jest system OMEGA. Podstawą jego działania jest stosowanie programowania genetycznego wspomagającego ocenę i prognozowanie ryzyka kredytowego. Na podstawie zbudowanego przez system modelu przyporządkowuje się składanym wnioskom kredytowym odpowiednią liczbę punktów. Z kolei na podstawie przyznanych punktów dokonuje się wyboru wniosków, które otrzymają pozytywną lub negatywną odpowiedź dotyczącą udzielenia kredytu.

Poszczególne elementy wchodzące w skład systemu oceny ryzyka kredytowego to OMEGA, GAAP oraz warstwa przetwarzania równoległego. OMEGA pełni tu funkcję elementu zarządzającego. GAAP (Genetic Algorithm for the Approximation of Formulae) jest algorytmem genetycznym opartym na modelu programowania genetycznego. Składa się on z dwóch etapów [11]. Pierwszy z nich polega na zdefiniowaniu środowiska, czyli m.in. postaci chromosomu, funkcji przystosowania, kryterium zatrzymania. Drugi z kolei polega na zastosowaniu algorytmu genetycznego. Ogólny schemat działania algorytmu genetycznego został przedstawiony w artykule „Przegląd algorytmów ewolucyjnych i ich zastosowań”. Trzeci z wymienionych elementów wchodzących w skład systemu, czyli warstwa przetwarzania równoległego, umożliwia zwiększenie efektywności algorytmu poprzez możliwość równoległego przetwarzania chromosomów na wielu procesach [11].

Tabela 3. Porównanie systemu OMEGA z systemem wykorzystującym sieć neuronową

	System dotychczasowy (sieć neuronowa)	OMEGA	Poprawa rezultatu
Współczynnik CoC	63,69%	65,15%	2,31%
Moc metody	2,54	2,41	5,12

Źródło: [11], s. 142.

Działanie tak skonstruowanego systemu do oceny ryzyka kredytowego zostało sprawdzone w jednym z brytyjskich banków. Efekty działania systemu OMEGA w porównaniu z systemem, który stosowany był w tym banku, przedstawione są w tabeli 3. Testy przeprowadzone zostały dla 5640 przypadków, przy uwzględnieniu 17 zmiennych prognozujących [11].

Na podstawie danych z tabeli 2 można zauważyć, że system wykorzystujący algorytm genetyczny daje lepsze rezultaty, w przypadku gdy mamy do czynienia z oceną ryzyka kredytowego.

4. Wnioski końcowe

Można zatem stwierdzić, że zastosowanie w ekonometrii rozwijających się metod optymalizacyjnych znajduje swoje uzasadnienie. Na podstawie przytoczonych badań [5], dotyczących zadania transportowego, widać, że możliwe było przeprowadzenie szybkiej analizy opisanego przypadku, a także określenie zmian, po wprowadzeniu których uzyskuje się zmniejszenie kosztów, a więc zwiększenie zysków. Stosowanie algorytmów genetycznych ma swoje uzasadnienia także w przypadku oceny ryzyka kredytowego. Przedstawiony system OMEGA – jak wynika z zamieszczonego wyżej porównania – może być dobrym narzędziem wspomagającym decyzje o tym, czy kredyt ma zostać udzielony, czy też nie. Zaletą stosowania opisanych algorytmów genetycznych jest również uzyskiwanie wyników w czasie krótszym niż w przypadku stosowania tradycyjnych metod badawczych, co jest istotne w rozstrzyganiu problemów decyzyjnych.

Bibliografia

- 1 Lange O., *Wstęp do ekonometrii*, [w:] *Dziela*, t. 5, Warszawa 1976.
- 2 Cegielski A., *Programowanie matematyczne*, cz. 1: *Programowanie liniowe*, Zielona Góra 2002.
- 3 Hozer J., Grzesiak S., *Zastosowanie programowania matematycznego w ekonomii*, Szczecin 1998.
- 4 Miszczyński M., *Programowanie liniowe. Elementy teorii i zadania*, Łódź 1997.
- 5 Załuski T., *Wykorzystanie programowania liniowego oraz algorytmów genetycznych do rozwiązywania liniowych zadań optymalizacyjnych z ograniczeniami*, Kraków 2004.
- 6 Arabas J., *Wykłady z algorytmów ewolucyjnych*, Warszawa 2001.
- 7 Kwaśnicka H., *Obliczenia ewolucyjne w sztucznej inteligencji*, Wrocław 1999.
- 8 Kwaśnicka H., *Sztuczna inteligencja. Algorytmy Ewolucyjne – Przykłady Zastosowań*, Wrocław 2002.
- 9 Michalewicz Z., *Algorytmy genetyczne + struktury danych = programy ewolucyjne*, Warszawa 1999.
- 10 Goldberg D.E., *Algorytmy genetyczne i ich zastosowania*, Warszawa 2003.
- 11 Gwiazda T.D., *Algorytmy genetyczne. Zastosowania w finansach*, Warszawa 1998.
- 12 http://brain.fuw.edu.pl/~jarek/MODELOWANIE/M1_wstep_dyskretne.pdf; 12.02.2006.